

PRETHODNO PRIPĆENJE

UDK 339.5(497.5):332.14

*Dr. sc. Goran Buturac***REGIONALNE SLIČNOSTI I RAZLIKE STRUKTURE
MEĐUNARODNE TRGOVINE U HRVATSKOJ****REGIONAL SIMILARITIES AND DIFFERENCES IN THE
INTERNATIONAL TRADE STRUCTURE IN CROATIA**

SAŽETAK: Cilj je ovoga rada analizirati sličnosti i razlike u strukturi međunarodne trgovine hrvatskih županija. Analiza je provedena primjenom k-means klaster metode. Kao ulazne varijable korišteni su pokazatelji strukture međunarodne trgovine, dok su županije Republike Hrvatske korištene kao objekti analize. Usporedba strukture međunarodne trgovine je provedena izračunom matrice euklidskih udaljenosti među županijama. Strukturu izvoza i uvoza Hrvatske obilježava izražena koncentracija, pri čemu Grad Zagreb ima najveći udio. Rezultati analize pokazuju postojanje značajnih razlika u strukturi međunarodne trgovine među hrvatskim županijama. Dobiveni klasteri najviše se razlikuju u usporedbi s klasterom 6, u kojemu je grupirana Ličko-senjska županija. Uspoređujući županije, može se ustvrditi da najveće razlike postoje između kontinentalnih i primorskih županija. Najveće sličnosti pokazuju Požeško-slavonska i Brodsko-posavska županija, zatim Zagrebačka i Bjelovarsko-bilogorska županija, te Karlovačka i Koprivničko-križevačka županija.

KLJUČNE RIJEČI: struktura međunarodne trgovine, k-means klaster metoda, euklidske udaljenosti, hrvatske županije.

ABSTRACT: The purpose of this paper is to analyze the similarities and differences in the international trade structure of Croatian counties. The analysis was conducted using the k-means cluster method. The indicators of international trade structure were used as input variables and Croatian counties were used as objects. The comparison of international trade structure was performed by calculating the matrix of Euclid distances between counties. The structure of export and import in Croatia is characterized by a strong concentration where City of Zagreb has the greatest share. The results point to the existence of considerable differences in the international trade structure of Croatian counties. The obtained clusters show the greatest difference in comparison with cluster 6, in which Ličko-senjska county is classified. The results show the greatest differences in the international trade structure between inland counties and coastal counties. Požeško-slavonska and Brodsko-posavska county have the greatest similarities, followed Zagrebačka and Bjelovarsko-bilogorska county, as well as, Karlovačka and Koprivničko-križevačka county.

KEY WORDS: international trade structure, k-means cluster method, Euclid distances, Croatian counties.

1. UVOD

U radu se analiziraju regionalne sličnosti i razlike strukture međunarodne trgovine u Hrvatskoj. Važnost teme naglašavaju integracijski procesi pri čemu je izražena potreba jačanja izvozne konkurentnosti svih regionalnih jedinica u cilju ravnomjernog gospodarskog razvoja. Iako je Hrvatska uspjela postići relativnu makroekonomsku stabilnost i liberalizirati svoje tržište, to nije pogodovalo održivom i ujednačenom gospodarskom razvoju hrvatskih regija. Gospodarske su razlike među hrvatskim županijama velike i u većini se slučajeva produbljuju /22, str. 48/. Promatrajući izdvojeno segment međunarodne trgovine, postavlja se pitanje razlika u izvoznim strukturama i komparativnim prednostima. Razdoblje tranzicije praćeno je procesima liberalizacije i integracije tržišta i obilježeno je značajnim promjenama u komparativnim prednostima i specijalizaciji u međunarodnoj trgovini /4, str. 475-489/. Moguće je očekivati da se te promjene odražavaju i na kretanja u međunarodnoj trgovini hrvatskih županija. Rezultiraju li te promjene i stvaranjem značajnijih disproporcija u izvoznim strukturama među hrvatskim regijama, pitanje je na koje se traži odgovor u empirijskoj analizi ovoga rada.

Analizirajući literaturu o međunarodnoj trgovini na razini regija, može se ustvrditi da je najveći broj radova usko vezan uz regionalne sporazume o trgovini i njihove učinke na ukupna trgovinska kretanja /9, str. 52-56; 13, str. 95-98; 21, str. 1-23/. Dio se radova fokusira na propitivanje korelacije između sporazuma o regionalnoj trgovini, geografske udaljenosti među regijama i promjena u ukupnim trgovinskim kretanjima. Rezultati pokazuju da sporazumi o regionalnoj trgovini imaju izraženije učinke na razvoj trgovine među regijama koje su geografski smještene bliže jedna drugoj /3, str. 1128-1148; 14 str. 202-226/. Određen broj radova bavi se propitivanjem učinaka razvoja regionalne trgovine na ukupna gospodarska kretanja pri čemu je ključno istraživačko pitanje rezultiraju li sporazumi o regionalnoj trgovini konvergencijom u razini gospodarskoga razvoja regija /7, str. 31-57; 10, str. 206; 26, str. 34/. Proces pridruživanja tranzicijskih zemalja središnje i istočne Europe Europskoj uniji dodatno je pobudio zanimanje istraživača za međunarodnu trgovinu na regionalnoj razini /8, str. 353-364; 15, str. 739-750; 19, str. 50/. Dosadašnja istraživanja u sklopu navedene teme u zemlji su oskudna. Poveznice se s empirijskom analizom provedenom u trećem dijelu rada mogu pronaći u primjeni multivarijatnih statističkih metoda poput k-means klaster metode. Domaća su recentna istraživanja, zasnovana na korištenju multivarijatnih statističkih metoda, ponajprije usmjerena na problematiku klasifikacije hrvatskih županija u veće homogene skupine na temelju socioekonomskih sličnosti /16, str. 1-15; 20, str. 1109-1160; 24, str. 53-76/.

Ovaj se rad zasniva na empirijskoj analizi koja je provedena primjenom k-means klaster metode. Pri tome se kao varijable analize koriste različiti pokazatelji strukture međunarodne trgovine, dok su objekti analize županije RH. Dobivenim rezultatima daju se odgovori na pitanja: postoje li značajnije razlike u strukturi međunarodne trgovine među hrvatskim županijama i koja su osnovna obilježja tih razlika? Osnova usporedbe strukture međunarodne trgovine je matrica euklidskih udaljenosti. Pri tome veće vrijednosti euklidskih udaljenosti podrazumijevaju i veću razliku. Obrnuto, manje vrijednosti ukazuju na veću sličnost strukture međunarodne trgovine.

Nakon uvoda, u drugome se dijelu rada analiziraju izvoz, uvoz i vanjskotrgovinska bilanca hrvatskih županija. U trećem, najvećem dijelu rada, provedena je empirijska analiza sličnosti i razlika strukture međunarodne trgovine među hrvatskim županijama. Na

početku je objašnjena metodološka osnova, a nakon toga su prikazani i interpretirani empirijski rezultati analize. Na kraju je rada zaključak.

2. IZVOZ, UVOZ I VANJSKOTRGOVINSKA BILANCA

Međunarodna trgovina Hrvatske proteklih je godina obilježena razdobljem tranzicije pri čemu su izraženi procesi ubrzanog otvaranja i integriranja te liberalizacije tržišta. Što je gospodarstvo otvorenije, veće su koristi od međunarodne trgovine, no veća je i izloženost utjecajima i kretanjima na međunarodnom tržištu. Dosadašnje teorijske spoznaje i empirijske potvrde idu u smjeru podrške otvorenim politikama međunarodne trgovine /25, str. 705-728/. Sve veća otvorenost nacionalnih ekonomija koja čini obilježje globalizacije, nameće nove izazove jačanju izvozne konkurentnosti. S obzirom na relativno malo domaće tržište te ograničenu raspoloživost prirodnih resursa, usmjerenost na međunarodnu trgovinu od neupitne je važnosti za Hrvatsku. Promatrajući kretanja na državnoj razini, može se ustvrditi da je čitavo razdoblje tranzicije bilo obilježeno snažnim rastom uvoza, dok je izvoz nakon početnih godina stagniranja u posljednjih nekoliko godina doživio blagi rast.¹ Takva su kretanja rezultirala i značajnim deficitom vanjskotrgovinske bilance.² Zbog procesa liberalizacije i otvaranja tržišta takvi su trendovi bili i očekivani na strani uvoza, ali se za izvoz može reći da nisu bili poželjni. Kretanja i razina izvoza predstavljaju jedan od najlošijih aspekata konkurentnosti Hrvatske. Lošiji trend rasta izvoza roba do sada je kompenzirao rast izvoza usluga od turizma /23, str. 79/.

Ukupna su izvozna kretanja rezultanta različitih trendova prisutnih unutar izvozne strukture gdje se mogu očekivati značajne regionalne razlike. Usporedba vrijednosti izvoza i uvoza među županijama pokazuje izdvojenost Grada Zagreba u odnosu na ostatak Hrvatske (tablica 1). Tako je u Gradu Zagrebu u godini 2005. ostvareno 43,4% ukupnoga izvoza Republike Hrvatske. Istovremeno druge županije nemaju zastupljenost u ukupnome izvozu veću od 10,0%. Nakon Grada Zagreba najveće udjele zauzimaju Istarska županija (8,3%) i Splitsko-dalmatinska županija (7,2%). Na začelju je Ličko-senjska županija koja ima udio izvoza u ukupnome hrvatskome izvozu 0,1%. Koncentracija uvoza još je izraženija u usporedbi s izvozom. Pri tome je u Gradu Zagrebu u godini 2005. ostvareno 62,1% ukupnoga uvoza Hrvatske. Slijede Zagrebačka i Primorsko-goranska županija čiji su udjeli u ukupnome uvozu na približno jednakoj razini (5,6%). Najveće suficite u međunarodnoj trgovini zabilježile su primorske županije i to: Dubrovačko-neretvanska županija, Zadarska županija i Istarska županija. Nasuprot tome, Grad Zagreb ima najveći deficit koji je približno jednak ukupnome deficitu Republike Hrvatske.

¹ Robni izvoz je u godini 1993. iznosio 29,4 milijarde kuna, a uvoz 32,8 milijardi kuna. U godini 2005. robni izvoz je iznosio 52,2 milijarde kuna, a uvoz 110,5 milijardi kuna /6, str. 807/.

² Vanjskotrgovinski deficit Republike Hrvatske je u godini 2005. iznosio 58,2 milijarde kuna, dok je pokrivenost uvoza izvozom u godini 2005. bila na razini 47,3 % /6, str. 807/.

Tablica 1. Izvoz, uvoz i vanjskotrgovinska bilanca hrvatskih županija u 2005. godini, izraženo u milijunima kuna

	Izvoz		Uvoz		Vanjsko-trgovinska bilanca
	Aps.	%	Aps.	%	
Zagrebačka	2.134	3,0	6.014	5,6	-3.880
Krapinsko-zagorska	1.455	2,0	1.369	1,3	87
Sisačko-moslavačka	1.715	2,4	1.055	1,0	661
Karlovačka	925	1,3	919	0,9	6
Varaždinska	3.448	4,8	3.569	3,3	-121
Koprivničko-križevačka	1.198	1,7	1.145	1,1	53
Bjelovarsko-bilogorska	654	0,9	699	0,7	45
Primorsko-goranska	4.803	6,8	5.978	5,6	-1175
Ličko-senjska	66	0,1	22	0,0	43
Virovitičko-podravska	656	0,9	448	0,4	207
Požeško-slavonska	426	0,6	295	0,3	131
Brodsko-posavska	634	0,9	603	0,6	32
Zadarska	2.159	3,0	1.097	1,0	1.063
Osječko-baranjska	3.259	4,6	2.929	2,7	330
Šibensko-kninska	1.242	1,7	1.211	1,1	31
Vukovarsko-srijemska	961	1,4	920	0,9	40
Splitsko-dalmatinska	5.105	7,2	5.176	4,8	71
Istarska	5.880	8,3	5.122	4,8	758
Dubrovačko-neretvanska	2.276	3,2	638	0,6	1.638
Međimurska	1.294	1,8	1.332	1,2	38
Grad Zagreb	30.865	43,4	66.500	62,1	-35.635
Ukupno Hrvatska	71.156	100,0	107.041	100,0	-35.885

Izvor: Državni zavod za statistiku Republike Hrvatske.

Prikazani rezultati potvrđuju postojanje značajnih disproporcija između hrvatskih regija u međunarodnoj trgovini. Slijedom toga mogu se očekivati i značajne razlike u strukturi međunarodne trgovine. Usporedba je strukture međunarodne trgovine hrvatskih županija provedena u empirijskoj analizi u nastavku rada.

3. EMPIRIJSKA ANALIZA

3.1. Metodološki okvir

Metodološka osnova provedbe kvantitativne analize zasniva se na primjeni k-means klaster metode i odgovarajućih standardiziranih pokazatelja strukture međunarodne trgovine. Algoritam rada k-means klaster metode je sljedeći: najprije se dobiva statistički formirani centar klastera i to procedurom u kojoj se prvo objekti razvrstavaju prema njihovoj međusobnoj udaljenosti. Nakon toga se odabire k centara klastera (k je unaprijed zadani broj klastera) u pokušaju da se svi objekti svrstaju u k klastera, i to pridruživanjem odabranim centrima klastera prema njihovoj udaljenosti od početnog centra klastera. Opisana procedura se ponavlja sve dok se ne odaberu centri klastera koji omogućuju grupiranje svih objekata u k klastera koje rezultira najboljom signifikantnošću rezultata ANOVA analize.

Kod k-means klaster metode udaljenosti među objektima i između objekata i centara klastera izražavaju se neskaliranim kvadriranim euklidskim udaljenostima. Na primjer, udaljenost $D(i, k)$ objekta i od centra klastera k za M analiziranih varijabli X_j se računa prema formuli:

$$D(i, k) = \sqrt{\frac{1}{M} \sum_{j=1}^M X_{ij} - \bar{X}_j^{(k)} }^2 \quad (1)$$

gdje je $\bar{X}_j^{(k)}$ srednja vrijednost varijable j za klaster k .

U prikazanoj se formuli (1) vidi da vrijednosti varijabli nisu reskalirane ni na koji način, pa se udaljenosti među pojedinim objektima i između objekata i centara klastera izražavaju u mjernim jedinicama analiziranih varijabli.

U k-means klaster analizi se za ulazne varijable koristi sljedećim pokazateljima: izvoz per capita, izvozna produktivnost, udio izvoza u bruto dodanoj vrijednosti, udio izvoza usluga u ukupnome izvozu, udio izvoza usluga u ukupnome izvozu, udio izvoza prerađivačke industrije u ukupnome izvozu. Uz navedeno, za ulazne varijable se koristi i standardiziranim pokazateljima strukture međunarodne trgovine, a to su:

Pokazatelj komparativnih prednosti, RCA pokazatelj

"Grubel-Lloydov indeks", GL indeks

Indeks entropije.

RCA pokazateljem se analiziraju komparativne prednosti. Razvio ga je 1965. godine Balassa. Izračunava se prema formuli:

$$RCA = \ln \frac{X_i}{M_i} \frac{\sum_{i=1}^n X_i}{\sum_{i=1}^n M_i} \cdot 100 \quad (2)$$

pri čemu X predstavlja vrijednost izvoza, dok je M oznaka za vrijednost uvoza. Indeks i označuje pojedini gospodarski sektor. Pozitivne vrijednosti RCA pokazatelja za određeni sektor pokazuju da zemlja ima izražene komparativne prednosti u proizvodnji i razmjeni toga sektora (2). Obrnuto, negativan predznak RCA pokazatelja pokazuje da zemlja nema komparativne prednosti.

U svrhu razvoja metodologije izračuna i primjene RCA pokazatelja napravljena su mnoga istraživanja /1, str. 41-62; 2, str. 99-123; 17, str. 209-234; 18, str. 13/. Najrašireniji je u primjeni koncept Balassinoga RCA pokazatelja koji predstavlja logaritamsku vrijednost relativne pokrivenosti uvoza izvozom kod pojedinoga proizvoda ili sektora prema pokrivenosti na razini gospodarstva /5, str. 471-487; 11, str. 399-423; 12, str. 54; 27, str. 74-100/. Stavljajući u odnos RCA pokazatelj s neoklasičnim teorijama komparativnih prednosti (Ricardo, Heckscher-Ohlin, Vanek, Leamer), može se ustvrditi da su empirijske vrijednosti RCA pokazatelja pokušaj svojevrsne aproksimacije u odnosu na rezultate istraživanja spomenutih teorijskih koncepata. Tako je primjerice prema Ricardu struktura robne razmjene određena različitim proizvodnim funkcijama zemalja sudionika u razmjeni. Razlike u proizvodnim funkcijama dovode i do razlike u produktivnosti rada. Razlike u relativnim produktivnostima rada u pojedinim proizvodima određuju i strukturu međunarodne trgovine. Zemlja će se specijalizirati u proizvodnji i izvozu onoga proizvoda u kojemu je relativna produktivnost rada veća. Drugim riječima, prema Ricardovoj teoriji komparativnih prednosti međunarodna trgovina se obavlja tako da svaka zemlja proizvodi za svjetsko tržište onu robu za koju ima relativne prednosti, tj. onu robu koju među mnogim mogućim robama proizvodi najekonomičnije. Koncept RCA pokazatelja je postavljen na način da zemlja ostvaruje komparativne prednosti u onim proizvodima gdje vrijednost izvoza premašuje vrijednost uvoza. Uz postojanje pretpostavke da se zemlja specijalizirala u proizvodnji onih dobara koje može proizvesti jeftinije u odnosu na ostatak svijeta, vrijednosti RCA pokazatelja mogu ukazivati na komparativne prednosti u onim sektorima gdje RCA pokazatelj poprima pozitivne vrijednosti (izvoz je veći od uvoza).

GL indeksom se koristi u analizi razine specijalizacije u intra-industrijskoj razmjeni pojedinoga gospodarskoga sektora. Metodologiju su izračuna GL indeksa razvili i primijenili Grubel i Lloyd (1975.).

GL indeks na sektorskoj razini izračunava se na sljedeći način:

$$GL_i = \frac{\sum_{i=1}^n (X_i - M_i) \left| \sum_{i=1}^n (X_i - M_i) \right|}{\sum_{i=1}^n (X_i - M_i)} \quad (3)$$

GL_i je vrijednost Grubel-Lloydovog indeksa za sektor i . X predstavlja vrijednost izvoza, a M vrijednost uvoza. Indeks se kreće u rasponu od 0 do 1. Veća vrijednost indeksa označuje veću razinu specijalizacije u intra-industrijskoj razmjeni (3).

Disperzija i koncentracija sektora u međunarodnoj trgovini analizirana je primjenom empirijskih izračuna TEI pokazatelja ("*Trade Entropy Index*"). Izračunava se prema sljedećoj formuli:

$$I_{xi} = \sum_j b_{ij} \ln \frac{1}{b_{ij}} \quad (4)$$

pri čemu vrijedi: $0 < b_{ij} < 1$; $\sum_j b_{ij} = 1$

Udio izvoza pojedinog sektora i u ukupnom izvozu županije j je označen b_{ij} . Isto vrijedi i za uvoz. Veća vrijednost ovoga pokazatelja ukazuje na veću razinu disperzije i obrnuto (4).

Kao izvori podataka u analizi se koriste podatci Državnoga zavoda za statistiku Republike Hrvatske. Ulazne su varijable u analizi odgovarajući pokazatelji strukture međunarodne trgovine, a objekti su analize županije Republike Hrvatske.

3.2. Empirijski rezultati

Obilježje je k-means klaster metode da se unaprijed odredi broj klastera pa se testira signifikantnost dobivenog rješenja. Test signifikantnosti u ANOVA-i ispituje varijabilnost između skupine s varijabilnošću unutar skupina. Pri tom se testira hipoteza da se sredine između skupina međusobno razlikuju. Test signifikantnosti je napravljen u nekoliko koraka. Najprije je propitana razina signifikantnosti za dva klastera. Nakon što dobiveni rezultati nisu bili signifikantni, pristupilo se sljedećim koracima u testiranju gdje je u svakom idućem koraku broj klastera uvećavan za jedinicu. Dobiveno je optimalno rješenje za šest klastera. Uz teorijsku razinu signifikantnosti od 5%, rezultati su ANOVA-e za šest predloženih klastera signifikantni (tablica 2).

Promatrajući raspodjelu županija prema dobivenim klasterima, može se zapaziti grupiranje primorskih županija (Istarska, Zadarska, Šibensko-kninska, Dubrovačko-neretvanska) u klasteru 3. Izuzetak su Splitsko-dalmatinska i Primorsko-goranska koje se nalaze u klasteru 1 (tablica 3). Atipičnosti pokazuju Ličko-senjska županija koja je jedina grupirana u klaster 6 kao i Grad Zagreb i Varaždinska županija koji zajedno čine klaster 2.

Tablica 2. ANOVA - analiza varijance za šest klastera

Varijabla	Suma kvadrata između klastera (SS)	Stupnjevi slobode (df)	Suma kvadrata unutar klastera (SS)	Stupnjevi slobode (df)	F omjer	p vrijednost
RCA pokazatelj	14,4438	5	15	15	2,9855	0,0457
GL indeks	0,2279	5	0	15	1,5391	0,0236
Izvoz <i>per capita</i>	1,1222E+09	5	458207300	15	7,3476	0,0011
Indeks entropije	0,9220	5	3	15	1,0178	0,0044
Izvozna produktivnost*	1,8377E+10	5	951071900	15	57,9668	0,0000
Udio izvoza u BDV**	0,2010	5	0	15	28,3678	0,0000
Udio izvoza usluga	0,4844	5	1	15	2,5770	0,0007
Udio izvoza županije u ukupnom izvozu RH	0,0875	5	0	15	3,3075	0,0327
Udio izvoza prerađivačke industrije	0,4810	5	1	15	2,4700	0,0080

*Izvozna produktivnost je izračunata kao omjer vrijednosti izvoza i broja zaposlenih.

**BDV je kratica za bruto dodanu vrijednost županije.

Izvor: Izračun autora.

Tablica 3. Prikaz raspodjele županija prema dobivenim klasterima

	Županije
<i>Klaster 1</i>	Krapinsko-zagorska, Sisačko-moslavačka, Osječko-baranjska, Primorsko-goranska, Splitsko-dalmatinska
<i>Klaster 2</i>	Grad Zagreb, Varaždinska
<i>Klaster 3</i>	Zadarska, Šibensko-kninska, Istarska, Dubrovačko-neretvanska
<i>Klaster 4</i>	Karlovačka, Koprivničko-križevačka, Virovitičko-podravska, Vukovarsko-srijemska, Međimurska
<i>Klaster 5</i>	Zagrebačka, Bjelovarsko-bilogorska, Požeško-slavonska, Brodsko-posavska
<i>Klaster 6</i>	Ličko-senjska

Izvor: Izračun autora.

U klasteru 1 su grupirane županije: Krapinsko-zagorska, Sisačko-moslavačka, Osječko-baranjska, Primorsko-goranska, Splitsko-dalmatinska. Obilježje je ovoga klastera dominacija izvoza prerađivačke industrije u ukupnome izvozu (tablica 4). Tu se također ostvaruje iznad-prosječna izvozna produktivnost. Izražena je specijalizacija u intra-industrijskoj razmjeni ($GL=0,91$), a prosječna je vrijednost pokazatelja komparativnih prednosti pozitivna ($RCA=0,16$).

Za klaster 2 u kojem se nalaze Grad Zagreb i Varaždinska županija, uočljiva je zamjetno veća vrijednost izvoza per capita u odnosu na preostale klasterne. U usporedbi s drugim klasterima, Grad Zagreb i Varaždinska županija imaju najveće udjele izvoza u bruto dodanoj vrijednosti. U ovom klasteru također prevladava specijalizacija u intra-industrijskoj razmjeni. Prosječna je vrijednost pokazatelja komparativnih prednosti negativna što se može povezati sa značajnim deficitom vanjskotrgovinske bilance koji se ponajprije ostvaruje u Gradu Zagrebu.

Očekivano klaster 3 koji sadrži većinu primorskih županija³ ima najveći udio izvoza usluga u odnosu na druge klasterne. Ovaj klaster županija ostvaruje najveću izvoznu produktivnost. Također, nakon klastera 2 u ovom klasteru je zabilježena najveća vrijednost izvoza per capita. Važno je izdvojiti Istarsku županija koja, s obzirom na pokazatelje izvozne produktivnosti, komparativnih prednosti i specijalizacije u međunarodnoj razmjeni, pokazuje najbolje rezultate u odnosu na druge hrvatske županije.

Klaster 4 sadrži županije koje pripadaju kontinentalnom dijelu zemlje, a to su: Karlovačka, Koprivničko-križevačka, Virovitičko-podravska, Vukovarsko-srijemska i Međimurska županija. Obilježje je ovoga klastera izražena koncentracija izvoza pri čemu dominaciju u izvozu imaju proizvodi prerađivačke industrije, i to ponajprije prehrambene. Izražena je specijalizacija u intra-industrijskoj razmjeni ($GL=0,95$), a prosječna je vrijednost pokazatelja komparativnih prednosti pozitivna ($RCA=0,13$).

³ Zadarska županija, Šibensko-kninska županija, Istarska županija i Dubrovačko-neretvanska županija.

Tablica 4. Srednje vrijednosti klastera

<i>Varijabla</i>	<i>Klaster 1</i>	<i>Klaster 2</i>	<i>Klaster 3</i>	<i>Klaster 4</i>	<i>Klaster 5</i>	<i>Klaster 6</i>
RCA pokazatelj	0,16	-0,19	1,5	0,13	0,04	3,19
GL indeks	0,91	0,81	0,80	0,95	0,82	0,51
Izvoz <i>per capita</i>	11.212,55	29.138,25	17.836,50	7.758,43	5.088,91	1.223,86
Indeks entropije	2,32	2,70	2,0	2,13	2,38	2,27
Izvozna produktivnost*	82.878,46	98.255,97	125.702,10	63.687,05	48.440,32	16.220,52
Udio izvoza u BDV**	0,26	0,42	0,32	0,20	0,14	0,03
Udio izvoza usluga	0,23	0,27	0,51	0,11	0,25	0,51
Udio izvoza županije u ukupnom izvozu RH	0,05	0,24	0,00	0,01	0,01	0,00
Udio izvoza prerađivačke industrije	0,74	0,65	0,40	0,83	0,71	0,41

*Izvozna produktivnost je izračunata kao omjer vrijednosti izvoza i broja zaposlenih.

**BDV je kratica za bruto dodanu vrijednost županije.

Izvor: Izračun autora.

U klasteru 5 nalaze se također kontinentalne županije i to: Zagrebačka, Bjelovarsko-bilogorska, Požeško-slavonska i Brodsko-posavska županija. Nakon klastera 6 kojem pripada Ličko-senjska županija, ovaj klaster županija ostvaruje najmanju izvoznu produktivnost i izvoz per capita. Ipak, valja istaknuti da Zagrebačka i Bjelovarsko-bilogorska županija bilježe bolje izvozne rezultate u odnosu na Brodsko-posavsku i Požeško-slavonsku županiju. Atipičnost je ovoga klastera podjednaka zastupljenost specijalizacije u intra-industrijskoj i inter-industrijskoj razmjeni ($GL=0,51$). Prosječna je vrijednost pokazatelja komparativnih prednosti pozitivna ($RCA=0,04$), no vrlo blizu 0.

Ličko-senjska županija je jedina županija grupirana u klaster 6. Prosječna je vrijednost pokazatelja komparativnih prednosti pozitivna ($RCA=3,19$) i ujedno je to najveća vrijednost ovoga pokazatelja u usporedbi s drugim klasterima. Obilježje je strukture izvoza Ličko-senjske županije dominacija poljoprivrednih i prehrambenih proizvoda i proizvoda drvne industrije. U tim je sektorima utvrđeno postojanje komparativnih prednosti ($RCA>0$), no u njima se ostvaruje mala dodana vrijednost.

Analiza srednjih vrijednosti ulaznih varijabli potvrđuje postojanje značajnih razlika u strukturi međunarodne trgovine formiranih klastera. Ono što je zajedničko svim klasterima, to je izražena specijalizacija u intra-industrijskoj razmjeni ($GL>0,50$) i naglašena koncentracija izvoza pri čemu u izvoznim strukturama županija dominira mali broj sektora. Sve ostale vrijednosti ulaznih varijabli potvrđuju značajne razlike, a najveće se disproporcije ogledaju u varijablama: izvoz per capita, izvozna produktivnost i udio izvoza u BDV.

Usporedba sličnosti i razlika strukture međunarodne trgovine među klasterima i među županijama provedena je izračunom matrice euklidskih udaljenosti (tablica 5). Veće vrijednosti euklidskih udaljenosti podrazumijevaju i veću razliku u strukturi međunarodne trgovine. Nasuprot tome, manje vrijednosti euklidskih udaljenosti podrazumijevaju veću sličnost u strukturi međunarodne trgovine. Promatrajući vrijednosti euklidskih udaljenosti, može se ustvrditi da najveću atipičnost pokazuje klaster 6 u kojemu je grupirana Ličko-senjska županija. Pri tome svi klasteri imaju najveće razlike upravo u odnosu na taj klaster. Najveća je razlika između klastera 3, u kojemu je grupiran najveći broj primorskih županija,⁴ i klastera 6.

⁴ U klasteru 3 su grupirane slijedeće županije: Istarska, Zadarska, Šibensko-kninska i Dubrovačko-neretvanska županija.

Tablica 5. Matrica euklidskih udaljenosti među klasterima

	Klaster 1	Klaster 2	Klaster 3	Klaster 4	Klaster 5	Klaster 6
Klaster 1	0	61.977.600	208.638.000	42.249.040	135.942.700	504.783.900
Klaster 2	7.872	0	97.891.240	183.567.400	339.996.600	834.336.500
Klaster 3	14.444	9.894	0	438.604.000	681.320.600	1.362.467.000
Klaster 4	6.499	13.549	20.943	0	26.620.990	255.085.800
Klaster 5	11.659	18.439	26.102	5.160	0	117.006.100
Klaster 6	22.467	28.885	36.912	15.971	10.817	0

Izvor: izračun autora.

Najveće sličnosti u strukturi međunarodne trgovine pokazuju klaster 4⁵ i klaster 5⁶. Zapaža se da klaster 3 s primorskim županijama ima značajne razlike u usporedbi s klasterima 4 i 5 gdje su smještene županije koje pripadaju kontinentalnom dijelu zemlje. Izdvojenost potvrđuju Grad Zagreb i Varaždinska županija koji, iako smješteni u kontinentalnom dijelu Hrvatske, pokazuju veću sličnost s klasterom primorskih županija nego sa klasterima u kojima se nalaze županije iz kontinentalnog dijela zemlje. Dobiveni rezultati idu u smjeru zaključka da najveće razlike u strukturi međunarodne trgovine postoje kad uspoređujemo pojedine kontinentalne županije s primorskim županijama. Svojevrnsne atipičnosti pokazuju s jedne strane Ličko-senjska županija i s druge strane klaster s Gradom Zagrebom i Varaždinskom županijom.

Nakon što su utvrđene sličnosti i razlike strukture međunarodne trgovine među klasterima, postavlja se pitanje sličnosti i razlika među županijama unutar pojedinih klastera. U tu su svrhu izračunate euklidske udaljenosti među županijama za svaki pojedini klaster. Uz to izračunata je prosječna vrijednost i standardna devijacija euklidskih udaljenosti (tablica 6).

⁵ U klasteru 4 su grupirane sljedeće županije: Karlovačka, Koprivničko-križevačka, Virovitičko-podravska, Vukovarsko-srijemska i Međimurska županija.

⁶ U klasteru 5 su grupirane sljedeće županije: Zagrebačka, Bjelovarsko-bilogorska, Požeško-slavonska i Brodsko-posavska županija.

Tablica 6. Euklidske udaljenosti, prosjek i standardna devijacija pojedinih klastera

<i>Klaster 1</i>	<i>Euklidske udaljenosti</i>	<i>Prosjek</i>	<i>Standardna devijacija</i>
Krapinsko-zagorska	3578,77	2606,222	723,7399
Sisačko-moslavačka	2448,49		
Primorsko-goranska	1607,22		
Osječko-baranjska	2464,33		
Splitsko-dalmatinska	2932,31		
<i>Klaster 2</i>	<i>Euklidske udaljenosti</i>	<i>Prosjek</i>	<i>Standardna devijacija</i>
Varaždinska	3603,60	3603,60	0
Grad Zagreb	3603,60		
<i>Klaster 3</i>	<i>Euklidske udaljenosti</i>	<i>Prosjek</i>	<i>Standardna devijacija</i>
Zadarska	3343,56	3782,843	1619,306
Šibensko-kninska	5208,66		
Istarska	4894,87		
Dubrovačko-neretvanska	1684,29		
<i>Klaster 4</i>	<i>Euklidske udaljenosti</i>	<i>Prosjek</i>	<i>Standardna devijacija</i>
Karlovačka	417,40	1625,482	1039,906
Koprivničko-križevačka	769,13		
Virovitičko-podravska	2987,25		
Vukovarsko-srijemska	2102,37		
Međimurska	1851,26		
<i>Klaster 5</i>	<i>Euklidske udaljenosti</i>	<i>Prosjek</i>	<i>Standardna devijacija</i>
Zagrebačka	2027,50	1682,527	443,9424
Bjelovarsko-bilogorska	2103,29		
Požeško-slavonska	1331,52		
Brodsko-posavska	1267,80		
<i>Klaster 6</i>	<i>Euklidske udaljenosti</i>	<i>Prosjek</i>	<i>Standardna devijacija</i>
Ličko-senjska	0,00	0	0

Izvor: Izračun autora.

Veća standardna devijacija podrazumijeva veće prosječno odstupanje među euklidskim udaljenostima, a to znači i postojanje većih razlika u strukturi međunarodne trgovine među županijama. Tako najveće razlike postoje u klasteru 3, a najmanje u klasteru 5. Razloge značajnijih odstupanja unutar klastera 3 valja tražiti u izraženoj atipičnosti koju

pokazuje Dubrovačko-neretvanska županija u usporedbi sa županijama: Istarskom, Zadarskom i Šibensko-kninskom. Obilježje je izvozne strukture Dubrovačko-neretvanske županije apsolutna dominacija uslužnog sektora, što nije slučaj u preostale tri županije koje, osim uslužnoga sektora, imaju značajnu zastupljenost pojedinih sektora prerađivačke industrije kao i razvijene komparativne prednosti u njima.⁷

U klasteru 5, unutar kojega su zabilježene najveće sličnosti, se zapaža da Zagrebačka i Bjelovarsko-bilogorska županija pokazuju međusobno veću sličnost s jedne strane, a Požeško-slavonska i Brodsko-posavska županija s druge strane. Slični su rezultati zabilježeni u klasteru 4, gdje Koprivničko-križevačka i Karlovačka županija pokazuju veće sličnosti u usporedbi sa županijama: Virovitičko-podravskom, Vukovarsko-srijemskom i Međimurskom.

Promatrajući sličnosti strukture međunarodne trgovine među hrvatskim županijama, može se ustvrditi da najveće sličnosti pokazuju Požeško-slavonska i Brodsko-posavska županija, zatim Zagrebačka i Bjelovarsko-bilogorska županija te Karlovačka i Koprivničko-križevačka županija.

4. ZAKLJUČAK

Usporedba vrijednosti izvoza i uvoza hrvatskih županija potvrđuje postojanje značajnih razlika u međunarodnoj trgovini. Obilježje je međunarodne trgovine Hrvatske značajna dominacija Grada Zagreba u strukturi izvoza i uvoza. Isto se tako u Gradu Zagrebu ostvaruje najveći deficit međunarodne trgovine pri čemu je njegova veličina na približno jednakoj razini ukupnoga deficita Republike Hrvatske. Analizirajući sličnosti i razlike strukture međunarodne trgovine k-means klaster metodom, dobiveno je šest klastera u kojima su grupirane hrvatske županije. Test signifikantnosti proveden ANOVA-om ukazuje da se sredine pojedinih klastera signifikantno razlikuju. Analiza srednjih vrijednosti ulaznih varijabli potvrđuje postojanje značajnih razlika u strukturi međunarodne trgovine među formiranim klasterima. Obilježje je svih klastera izražena specijalizacija u intra-industrijskoj razmjeni i naglašena koncentracija izvoza pri čemu u izvoznim strukturama županija dominira mali broj gospodarskih sektora. Ostale prikazane vrijednosti ulaznih varijabli potvrđuju značajne razlike u strukturi međunarodne trgovine koje su najviše naglašene u varijablama: izvoz per capita, izvozna produktivnost i udio izvoza u BDV. Najveće su razlike u strukturi međunarodne trgovine između kontinentalnih i primorskih županija. Svojevrstne atipičnosti pokazuju s jedne strane Ličko-senjska županija i s druge strane klaster s Gradom Zagrebom i Varaždinskom županijom. Dobiveni klasteri pokazuju najveće razlike u usporedbi s klasterom 6 u kojemu se nalazi Ličko-senjska županija. Grad Zagreb, iako geografski smješten u kontinentalnom dijelu Hrvatske, pokazuje veću sličnost s klasterom primorskih županija nego s klasterima u kojima se nalaze županije iz kontinentalnog dijela zemlje. Analiza sličnosti strukture međunarodne trgovine hrvatskih županija pokazuje da najveće sličnosti postoje između Požeško-slavonske i Brodsko-posavske županije, zatim Zagrebačke i Bjelovarsko-bilogorske županije te Karlovačke i Koprivničko-križevačke županije.

⁷ Udio je izvoza usluga u ukupnome izvozu Dubrovačko-neretvanske županije u godini 2005. iznosio 91,0% /6, str. 807/.

LITERATURA

1. Aquino, A. (1981). "Change over time in the pattern of comparative advantage in manufactured goods: An empirical analysis for the period 1972-1974", *European Economic Review*, (15), 1: 41-62.
2. Balassa, B. (1965). "Trade Liberalization and Revealed Comparative Advantage", *Manchester School of Economic and Social Studies*, (33), 2: 99-123.
3. Bhagwati, J., Greenway, D., Panagariya, A. (1998.). "Trading preferentially: theory and policy", *Economic Journal*, (108), 1: 1128-1148.
4. Buturac, G. (2006.). "Horizontalna i vertikalna specijalizacija u međunarodnoj robnoj razmjeni: slučaj Hrvatske i Češke", *Ekonomski pregled*, (57), 7-8: 475-489.
5. Djankov, S., Hoekman, B. (1997.). "Determinants of the Export Structure of Countries in Central and Eastern Europe", *The World Bank Economic Review*, (11), 3: 471-487.
6. Državni zavod za statistiku Republike Hrvatske, (2007.). *Statistički ljetopis Republike Hrvatske, 2007.*, Zagreb: Državni zavod za statistiku Republike Hrvatske, str. 807.
7. Edwards, S. (1992.). "Trade Orientation, Distorsions and Growth in Developing Countries", *Journal of Development Economics*, (39), 1: 31-57.
8. Esteban, J. (2000.). "Regional convergence in Europe and the industry mix: a shift-share analysis", *Regional Science and Urban Economics*, (30), 3: 353-364.
9. Frankel, J.A., Stein, E., Wei, S. (1996.). "Regional trading arrangements: natural or supernatural?", *American Economic Review*, (86), 2: 52-56.
10. Grubel, H., Lloyd, P. (1975.). *Intra-industry Trade: The Theory and Measurement of International Trade in Differentiated Products*. London: Macmillan
11. Landesmann, M., Stehrer, R. (2001.). "Convergence patterns and switchovers in comparative advantage," *Structural Change and Economic Dynamics*, Elsevier, (12), 4: 399-423.
12. Kaminski, B., Ng, F. (2001.). "Trade and Production Fragmentation: Central European Economies in EU Networks of Production and Marketing", *World Bank Policy Research Working Paper No. 2611*, Washington: World Bank.
13. Kemp, M. C., Wan H. (1976.). "An Elementary Proposition Concerning the Formation of Customs Unions", *Journal of International Economics*, (6), 1: 95-98.
14. Krishna, P. (2003.). "Are regional trading partners "natural"?", *Journal of Political Economy*, (111), 1: 202-226.
15. Kronthaler, F. (2005.). "Economic capability of East German regions: results of a cluster analysis", *Regional Studies, Taylor and Francis Journals*, (39), 6: 739-750.
16. Kurnoga Živadinović, N. (2007.). "Multivarijatna klasifikacija županija Hrvatske", *Zbornik Ekonomskog fakulteta u Zagrebu*, (5), 1: 1-15.
17. Lafay, G. (1992.). "The measurement of revealed comparative advantages," in M.G. Dagenais and P.A. Muet eds., *International Trade Modeling*. London: Chapman & Hill, str. 209-234.

18. Laursen, K. (1998.). "Revealed Comparative Advantage and the Alternatives as Measures of International Specialisation," *DRUID Working Papers 98-30*, DRUID, Copenhagen Business School.
19. Lemoine, F. (1998.). "Integrating Central and Eastern Europe In the European Trade and Production Network", UCAIS Berkeley Roundtable on the International Economy, *Working Paper Series 1063*, UC Berkeley.
20. Lovrinčević, Ž., Marić, Z., Rajh, E. (2005.). "Kako optimalno regionalizirati Hrvatsku?", *Ekonomski pregled*, (56), 12: 1109-1160.
21. Managi, S., Kawajiri, H., Tsurumi, T. (2005.). "Regional economic integration and trade: an empirical evaluation of NAFTA and EU", *International Journal of Agricultural Resources, Governance and Ecology*, (4), 1: 1-23.
22. Ministarstvo mora, turizma, prometa i razvitka, (2005.). *Strategija regionalnog razvoja Republike Hrvatske*, Zagreb: Ministarstvo mora, turizma, prometa i razvitka.
23. Nacionalno vijeće za konkurentnost, (2006.). *Godišnje izvješće o konkurentnosti Hrvatske 2006. godine*, Zagreb: Nacionalno vijeće za konkurentnost.
24. Rašić-Bakarić, I. (2006.). "Primjena faktorske i klaster analize u otkrivanju regionalnih nejednakosti", *Privredna kretanja i ekonomska politika*, (15), 105: 53-76.
25. Teodorović, I., Buturac, G. (2006.). "Perspektive industrijske proizvodnje u Hrvatskoj i intra-industrijska razmjena", *Ekonomski pregled*, (57), 11: 705-728.
26. Vamvakidis, A. (1998.). "Regional Trade Agreements Versus Board Liberalization: Which Path Leads to Faster Growth? Time Series Evidence", *Working Paper No.98/40*, International Monetary Fund.
27. Yilmaz, B. (2005.). "The Foreign Trade Pattern and Foreign Trade Specialization in the European Union: A Comparison of Six New Member/Candidate Countries and the EU/15", *Eastern European Economics*, (43), 5: 74-100.